

# Over blur를 감소시킨 Deep CNN 구현 Implementation of Deep CNN denoiser for Reducing Over blur

이 성 훈\*, 이 광 엽\*, 정 준 모\*<sup>★</sup>

Sung-Hun Lee\*, Kwang-Yeob Lee\*, Jun-Mo Jung\*<sup>★</sup>

## Abstract

In this paper, we have implemented a network that overcomes the over-blurring phenomenon that occurs when removing Gaussian noise. In the conventional filtering method, blurring of the original image is performed to remove noise, thereby eliminating high frequency components such as edges and corners. We propose a network that reducing over blurring while maintaining denoising performance by adding denoised high frequency components to denoisers based on CNN.

## 요 약

본 논문에서, Gaussian noise를 제거할 때 발생하는 over blurring 현상을 감소시키는 network를 구현하였다. 기존 filtering 방식은 원 영상을 blurring하여 noise를 제거함으로써, edge나 corner 같은 high frequency 성분도 함께 지워지는 것을 확인할 수 있다. CNN (Convolutional Neural Network)기반 denoiser의 경우도 사소한 edge, keypoint를 noise로 인식하여 이러한 정보를 잃게 된다. 우리는 CNN을 기반으로 denoising된 high frequency 성분만을 획득하여 기존 denoiser에 추가함으로써 denoising 성능을 유지하면서 over blurring을 완화하는 network 제안한다.

*Key words : Deep learning, Denoising, Image processing, Gaussian noise, Over blurring*

## 1. 서론

영상처리는 다양한 분야에서 사용되며, 그 활용 범위는 매우 넓다. 하지만 그 전에 선행되어야 할 점은 영상을 전송, 디지털화하는 과정에서 발생하는 noise를 제거하는 것으로, 이 noise가 다른 application의 성능을 현저히 낮추는 주요 원인이기 때문이다.[1]

대표적인 기존의 denoising 방법들은 filtering을 하여 영상을 blurring을 하는 방식이다. noise가 적을 경우, 원 영상과 품질 차이가 크지 않아 괜찮지만, noise가 많을 경우 영상의 high frequency 성분들이 사라져 형태를 구분하기 쉽지 않다. 최근에는 Deep Learning을 base로 한 연구들이 활발하며 기존 방법들과 비교해 성능도 검증되었다. 하지만 이

---

\* Dept. of Computer Engineering, Seokyeong University  
\* Dept. of Electronics Engineering, Seokyeong University  
★ Corresponding author  
E-mail : jjmo@skuniv.ac.kr, Tel : +82-2-940-7745  
※ Acknowledgment

This work was supported by Seokyeong University in 2018.

Manuscript received Dec. 12, 2018; revised Dec. 17, 2018; accepted Dec. 17, 2018

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

방법 역시 over blurring 현상이 발생한다. 본 논문에서는 이러한 over blur를 줄이고자 low frequency를 학습하여 잃어버린 edge, keypoint를 복원하는 방법을 제안하였다. denoiser의 target은 Gaussian noise이며 noise의 sigma는 25이다. 실험은 i7-4770 @ 3.40GHz, NVIDIA GTX 1070, RAM 20GB에서 진행하였으며 training dataset은 CelebA dataset[2]을 10stride 씩 옮겨 크기가 35x35가 되도록 patch를 만들어 사용하였다.

II. 본론

1. 구조

가. DnCNN

본 논문에서 제시하는 network의 denoising을 담당하는 부분은 DnCNN [3]을 참조하였다. 우리의 주 목적은 기존의 방법보다 월등한 denoising 성능이 아닌 denoising의 성능을 유지하되 잃어버린 edge, keypoint를 복구하기 위함으로 성능이 검증된 DnCNN model을 통해 denoising을 진행하였다. DnCNN의 layer는 총 17개의 layer로 구성되어 있으며 ResNet [4]의 shortcut connection을 통해 추론한 noise와 입력(noisy image)의 차이를 denoising 결과로 출력한다. 각 layer는 Convolution-Batch normalization-ReLu로 구성되며 첫 번째 layer는 Convolution-ReLu, 마지막 layer는 Convolution으로 구성되어 있다.




Fig. 1. DnCNN's architecture. 그림 1. DnCNN 구조

나. Learning for infer low frequency

본 논문에서 제시하는 low frequency를 추론하는 network는 ResNet Team의 Full pre-activation [5]을 이용하여 각 block은 Batch Normalization-ReLu-Convolution-Batch Normalization-ReLu-Convolution의 순으로 연산을 진행한다. 이러한 block이 총 9개로 구성하며 마지막 block은 convolution 연산만 수행한다. 각 layer는 64개의 filter가 존재하며 filter size는 3이다. 이러한 layer들은 DnCNN model과 직선상에 존재 하지 않는다. 즉, 초기 입력

y가 2개의 경로로 나뉘져 한 경로는 DnCNN의 입력으로, 나머지 다른 한 경로는 low frequency를 추론하는 network의 입력으로 들어간다.




Fig. 2. Proposed network's architecture. 그림 2. 제안하는 network 구조




Fig. 3. ResNet team's full pre-activation. 그림 3. ResNet team의 full pre-activation

2. 학습 방법

본 논문에서 제시하는 학습 방법은 noisy image를 입력으로 받아 각각 DnCNN과 low frequency를 검출하는 network에 입력된다. DnCNN의 parameter는 [3]에서 제시한 방법을 따랐으며 noise를 추론하도록 학습하여 입력과 감산을 통해 denoising된 결과를 출력한다. 이 때, 출력은 over blurring된 결과이다.

Low frequency를 획득하기 위해 기존이 filtering 방식을 사용하지 않고 CNN을 적용한 이유는 noise에 있다. 우리가 제안하는 network는 noisy영상을 입력받아 denoising된 low frequency를 출력한다. 따라서, 이 결과를 noisy 영상에 감산한다면 noise와 high frequency성분이 같이 있는 결과를 얻게되며, DnCNN에서 추론한 noise로 감산해 denoising된 high frequency를 얻을 수 있게 된다. 반면, 기존의 low frequency를 얻는 filtering 기법을 사용하게 된다면, low frequency 자체에도 일부 noise가 존재하게 되며(blur가 되었지만, noise가 완벽하게 제거된 결과가 아니다. 그림 4 참조) 이를 이용해 원 영상에서 감산을 하면, low frequency에서 지워진 noise가 존재하는 high frequency 성분이 출력된다. 따라서, 이 성분에 noise를 감산한다 하

여도 완벽하게 noise가 제거된 high frequency 성분을 얻을 수 없어 denoiser의 성능을 감소시킨다.



Fig. 4. Low frequency component.  
그림 4. Low frequency 성분




Fig. 5. Overall data flow.  
그림 5. 전반적인 데이터 흐름

Low frequency를 학습하는 방법에 대해 설명하기 전에 edge, keypoint와 같은 high frequency 성분을 복원하기 위해 high frequency, 그 자체를 추론하는 것이 아닌 low frequency를 추론하도록 network를 훈련시키는 이유에 대해 설명하고자 한다. high frequency 영상의 대부분의 화소들은 0의 값에 가깝기 때문에 추론 결과와 실제 high frequency의 차이가 작아도 그 둘이 유사하다고 말할 수 없다. 실제로 network를 학습할 때, high frequency dataset으로 학습한 경우보다 low frequency dataset으로 학습한 뒤 원 영상에 감산하여 high frequency 성분을 얻는 경우가 성능이 더 좋다는 결과를 얻을 수 있었다.

Low frequency를 추론하는 network는 learning rate decay 방식을 적용하며 epoch은 50, batch size는 128을 사용하였다. 제안한 network의 출력은 high frequency로 ResNet의 shortcut connection을 이용하여 추론한 low frequency와 입력 영상을 감

산한 결과이다. 하지만 이 결과에는 noise가 주변 pixel에 비해 차이가 커 high frequency로 인식돼 포함되어 있을 수 있다. 이를 위해 DnCNN에서 추론한 noise와 high frequency를 감산하여 noise가 제거된 high frequency를 얻을 수 있으며 DnCNN의 결과인 denoising된 영상에 이를 더함으로써 high frequency를 복원할 수 있다.

### 3. 실험 결과

본 논문에서 제시한 학습 방법 중 추론된 high frequency에 noise가 존재할 것이라는 전제를 DnCNN에서 추론된 noise와의 감산 여부를 통해 증명할 수 있었다. 즉, DnCNN에서 추론한 noise를 이용하여 감산을 한 경우와 하지 않은 경우 원본과의 PSNR이 0.5이상 차이가 존재했다.

Table 1. The PSNR according to subtraction.

표 1. 감산 여부에 따른 PSNR

Method	PSNR
not using subtract	28.28
using subtract	28.80

DnCNN은 기존 연구의 구조나 hyper parameter를 동일하게 적용하여 실험을 진행하였으며 high frequency 성분 복원을 위한 network는 high frequency와 low frequency를 학습할 경우로 나누어 진행하여 화소 정보가 많은 low frequency를 학습하는 것이 직접 high frequency를 학습하는 것보다 더 좋은 high frequency성분을 구할 수 있음을 denoising 결과와 원본과의 PSNR로 증명하였다. 이 실험의 결과는 표 2와 같다.

Table 2. The PSNR of each training method.

표 2. 학습방법에 따른 PSNR 결과

Training method	PSNR
High frequency	28.60
Low frequency	28.80

### III. 결론

본 논문에서는 Gaussian noise를 제거하는 filtering, CNN기반 denoiser들에서 찾아볼 수 있는 over

blurring 현상을 해결하고자 noisy 영상으로부터 noise 가 제거된 high frequency 성분을 추출하고 이를 기존 denoiser의 결과에 더하여 잃어버린 edge, corner와 같은 성분을 복원하는 network를 제안하였다. 또한 context information이 많은 low frequency 성분을 학습하여 high frequency를 얻는 것이 더 좋은 성능을 얻을 수 있다는 것도 실험을 통해 확인하였다. 제안한 network는 사람의 주름이나 물체의 edge와 같은 high frequency 성분을 더 잘 관찰할 수 있음을 Fig. 6, 7을 비교하여 확인할 수 있다.




Fig. 6. DnCNN's denoising result.  
그림 6. DnCNN의 denoising 결과




Fig. 7. Proposed network's result.  
그림 7. 제안하는 network의 결과

## References

- [1] Jeon, Yougn-Eun, et al. "Gaussian Noise Reduction Algorithm using Self-similarity," *Journal of the Institute of Electronics Engineers of Korea SP*, 44, 5, 1-10, 2007.
- [2] Multimedia Laboratory, "Large-scale CelebFaces

Attributes (CelebA) Dataset," <https://mmlab.ie.cuhk.edu.hk>

- [3] Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L, "Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising," *IEEE Transactions on Image Processing*, 26, 7, 3142-3155, 2017. DOI:10.1109/TIP.2017.2662206
- [4] He, K., Zhang, X., Ren, S., & Sun, J, "Deep residual learning for image recognition," *In Proceedings of the IEEE conference on computer vision and pattern recognition*. 770-778, 2016.
- [5] He, K., Zhang, X., Ren, S., & Sun, J., "Identity mappings in deep residual networks," *In European conference on computer vision*, (2016, October), 630-645.